Journal of **N**ovel **R**esearches on **S**mart **P**ower **S**ystems - Vol. 14 - No. 1 – Spring 2025
P-ISSN: 2322-2468, E-ISSN: 2981-0272, https://jeps.dezful.iau.ir/

Research Article

Detection of High Impedance Faults in Electrical Distribution Systems Based on the RF-ICEEMDAN Approach

Mohammad Sadegh Attar, *Master's Degree*
Department of Electrical Engineering, Tafresh University, Tafresh, Iran, pwr400.Attar@tafreshu.ac.ir

Abstract:
One of the most critical faults in electrical distribution networks, often leading to hazardous incidents such as fires, is the high impedance fault (HIF). Due to the low magnitude of the fault current, this type of fault typically remains undetected by conventional protection devices, such as overcurrent relays. Moreover, the amplitude variations and waveform of HIF currents closely resemble those of other phenomena, such as variations in linear and nonlinear loads. In this paper, a Random Forest classification algorithm combined with an improved noise-assisted Complete Ensemble Empirical Mode Decomposition with Adaptive Noise (ICEEMDAN) is employed solely for the identification of high impedance faults. In the proposed RF-ICEEMDAN method, the dataset consisting of measured current signals from high impedance faults and load variations is first collected. The ICEEMDAN method is then used to decompose the signals and extract features from each sample. The extracted features are fed into the Random Forest classification algorithm. The proposed approach is implemented on the IEEE 34-bus distribution test system. The results demonstrate high accuracy and effectiveness in detecting high impedance faults. For simulation and evaluation purposes, EMTP-RV software is used for modeling the power system, and Python programming in the Google Colab environment is utilized for feature extraction and implementation of the Random Forest algorithm. The obtained results confirm the high performance and reliability of the proposed approach.

Keywords: High impedance fault, Random forest, Load switching, Fault current, ICEEMDAN method

Received: 15 March 2025
Revised: 19 May 2025
Accepted: 28 May 2025

*** Corresponding Author:** Mohammad Sadegh Attar

Citation: Mohammad Sadegh Attar, “Detection of High Impedance Faults in Electrical Distribution Systems Based on the RF-ICEEMDAN Approach”, Journal of Novel Researches on Smart Power Systems, vol. 14, no. 1, pp. 83-103, June 2025 (in Persian)

[Downloaded from jeps.dezful.iau.ir on 2026-11-14]

[DOI: 10.82362/jeps.2025.1.533]

مقاله پژوهشی

تشخیص خطای امپدانس بالا در شبکه توزیع انرژی الکتریکی با استفاده از روش RF-ICEEMDAN

محمدصادق عطار، کارشناسی ارشد

۱- دانشکده مهندسی برق، دانشگاه تفرش، تفرش، ایران، pwr400.Attar@tafreshu.ac.ir

چکیده: از مهم‌ترین خطاها که در شبکه‌های توزیع انرژی الکتریکی منجر به حوادث ناگواری هم‌چون آتش‌سوزی می‌شود، خطای امپدانس بالا می‌باشد. این نوع از خطاها به‌دلیل پایین بودن دامنه جریان، توسط تجهیزات حفاظتی مرسوم، هم‌چون رله‌های اضافه جریان، تشخیص داده نمی‌شوند. از طرفی دامنه تغییرات و شکل موج جریان خطای امپدانس بالا نزدیک به پدیده‌های دیگری هم‌چون تغییرات بارهای خطی و غیرخطی می‌باشد. در این مقاله از الگوریتم طبقه‌بندی جنگل تصادفی به‌همراه بهبود یافته تجزیه تجربی کامل مجموعه‌ای با نویز تطبیقی به‌منظور تنها شناسایی خطای امپدانس بالا استفاده شده است. در روش RF-ICEEMDAN، ابتدا مجموعه داده‌ها که شامل سیگنال‌های جریان‌های اندازه‌گیری شده خطای امپدانس بالا و تغییرات بارها می‌باشد، جمع آوری می‌شوند. سپس توسط روش ICEEMDAN تجزیه می‌شود تا ویژگی‌های هر نمونه از مجموعه داده‌ها، استخراج شود. ویژگی‌های استخراج شده از این بخش به‌عنوان ورودی به الگوریتم طبقه‌بندی جنگل تصادفی مورداستفاده قرار می‌گیرد. روش پیشنهادی بر روی شبکه توزیع تست ۳۴ شینه IEEE پیاده‌سازی شده است. در این روش، توانایی و دقت بالا در تشخیص خطای امپدانس بالا قابل مشاهده است. به‌منظور شبیه‌سازی و بررسی روش پیشنهادی، از نرم‌افزارهای شبیه‌سازی EMTP-rv برای مدلسازی شبکه قدرت و از زبان برنامه‌نویسی Python در محیط Google Colab برای استخراج ویژگی و پیاده‌سازی الگوریتم جنگل تصادفی استفاده شده است. نتایج به‌دست آمده، دقت بالای روش پیشنهادی را تأیید می‌کند.

کلمات کلیدی: خطای امپدانس بالا، جنگل تصادفی، تغییرات بار، جریان خطا، روش ICEEMDAN

تاریخ دریافت: ۱۴۰۴/۱۲/۲۵
تاریخ بازنگری: ۱۴۰۴/۲/۲۹
تاریخ پذیرش: ۱۴۰۴/۳/۷

* **نام نویسنده مسئول:** محمدصادق عطار
نشانی نویسنده مسئول: تفرش، دانشگاه تفرش، دانشکده فنی و مهندسی، گروه مهندسی برق

[Downloaded from jeps.dezful.iau.ir on 2026-11-14]

[DOI: 10.82362/jeps.2025.1.533]
Journal of Novel Researches on Smart Power Systems - Vol. 14 - No. 1- Spring 2025

۱- مقدمه

انتقال انرژی الکتریکی با قابلیت اطمینان بالا از اولویت‌های اصلی در سیستم‌های قدرت می‌باشد. خطای امپدانس بالا[۱](HIF) ناشی از اتصال هادی برق‌دار به زمین از طریق یک جسم با امپدانس بالا است که معمولاً با قوس الکتریکی همراه است. به‌دلیل جریان کم این خطا که نزدیک به جریان بار است، رله‌های اضافه جریان قادر به شناسایی این خطا نیستند. لذا این موضوع چالشی مهم در شبکه‌های توزیع انرژی الکتریکی محسوب می‌شود. خطاهای امپدانس بالا ویژگی‌های غیرخطی مشابهی با پدیده‌هایی مانند سوئیچینگ بار، بانک‌های خازنی، و جریان هجومی ترانسفورماتورها دارند. این شباهت، شناسایی آن‌ها را پیچیده‌تر کرده و ضرورت استفاده از تجهیزات حفاظتی دقیق را افزایش می‌دهد. عدم تشخیص صحیح این خطاها می‌تواند به خطرات جدی، از جمله برق‌گرفتگی، تلفات جانی و مالی، قطعی شبکه، و حتی آتش‌سوزی منجر شود. بنابراین، شناسایی سریع و دقیق خطاهای امپدانس بالا از اهمیت بالایی برخوردار است [۱, ۲].

برای شناسایی خطاهای امپدانس بالا، روش‌های متنوعی ارائه شده است که بسیاری از آن‌ها بر پایه یادگیری ماشین هستند. در [۳] مطالعه‌ای جامع بر روی انواع روش‌ها به‌منظور تشخیص خطای امپدانس بالا و مقایسه این خطا با سایر پدیده‌های مشابه در شبکه‌های توزیع انرژی الکتریکی اشاره کرده است. به‌عنوان مثال، روش‌هایی مانند استفاده از ماشین بردار پشتیبان در تحلیل پیش‌بینی و ضعیت سیستم‌ها [۴] و هم‌چنین در تشخیص این نوع از خطاها [۹-۵]، کانولو شنال چگال[۲][۱۰]، و تکنیک‌های یادگیری عمیق مانند شبکه حافظه طولانی کوتاه‌مدت[۳](LSTM) [۱۱, ۱۲] توسعه یافته‌اند. برخی از پژوهش‌ها نیز از الگوریتم‌های مبتنی بر موجک [۱۵-۱۳] و مدل‌های شبکه عصبی [۱۸-۱۶] بهره برده‌اند. استفاده از تجزیه حالت تجربی و نسخه‌های پیشرفته آن در شناسایی خطاهای امپدانس بالا بسیار موردتوجه بوده است. در [۱۹]، از روش تجزیه حالت تجربی همراه با شبکه عصبی مصنوعی برای تحلیل سیگنال‌های قوس در زمان واقعی استفاده شده است. هم‌چنین، در [۲۰] از روش تجزیه حالت تجربی تجمعی کامل با داده کمکی نویز[۴] (CEEMDAN)، نسخه‌ای بهبودیافته از تجزیه حالت تجربی[۵] (EMD)، برای تشخیص خطای امپدانس بالا استفاده شده است. در [۲۱] از روش‌های یادگیری ماشین به‌ویژه تکنیک‌های بدون نظارت مانند خود رمزگذار[۶] و تحلیل مؤلفه‌های اصلی، به‌دلیل توانایی در شناسایی ناهنجاری‌ها بدون نیاز به داده‌های برچسب‌دار استفاده کرده است. این روش‌ها قادرند تغییرات ظریف در شکل موج جریان را که ناشی از خطاهای امپدانس بالا هستند، تشخیص دهند. مطالعات اخیر نشان داده‌اند که ترکیب این تکنیک‌ها با داده‌های شبیه‌سازی‌شده و واقعی می‌تواند دقت و قابلیت اطمینان تشخیص خطاهای امپدانس بالا را به‌طور قابل توجهی بهبود بخشد. در [۲۲] به تشخیص خطای امپدانس بالا در یک شبکه توزیع واقعی با استفاده از روش ترکیبی تبدیل موجک گسسته به‌همراه ماشین بردار پشتیبان اشاره کرده است. مرجع [۲۳]، یک روش نوین دو مرحله‌ای مبتنی بر داده برای تشخیص خطاهای امپدانس بالا پیشنهاد می‌کند که از تخمین امپدانس خط استفاده کرده و نتایج تخمین‌زده‌شده را با اطلاعات محل خطا تطبیق می‌دهد. این روش هر خط را به‌طور مجزا هدف قرار داده و امکان تشخیص دقیق خطاهای امپدانس بالا بین گره‌های اندازه‌گیری خاص را فراهم می‌کند. نتایج آزمایش‌ها روی سیستم ۳۳ شینه‌ی IEEE نشان می‌دهد که این روش قادر است خطاهای امپدانس بالا را در شرایط بدون نویز و با دقت ۹۱/۷۲٪ تشخیص دهد، که اثربخشی آن روش را تأیید می‌کند. مرجع [۲۴]، با استفاده از تشخیص‌دهنده‌های انرژی، راه‌حل‌هایی برای شبکه توزیع موجود پیشنهاد می‌کند. تشخیص‌دهنده انرژی از دو بخش اصلی تشکیل شده است: ۱) تشخیص‌دهنده انرژی مبتنی بر «ولتاژ سمت منفی - جریان سمت صفر» و ۲) تشخیص‌دهنده انرژی مبتنی بر «ولتاژ سمت منفی - جریان سمت منفی». این تشخیص‌دهنده‌ها در کنار رله‌های حفاظتی اضافه‌جریان موجود استفاده می‌شوند، به‌طوری‌که رله‌های اضافه‌جریان از خطای امپدانس بالا محافظت می‌کنند و تشخیص‌دهنده‌های انرژی، خطاهای امپدانس بالا را تشخیص می‌دهند. تشخیص‌دهنده‌ها بر اساس آستانه‌های انرژی تلف‌شده در طول خطاهای امپدانس بالا و مناطق همگرایی مربوطه عمل می‌کنند. عملکرد این سیستم روی یک سیستم ساده ۷ شینه در یک پلتفرم شبیه‌سازی آزمایش شده و با داده‌های واقعی از پست ۱۱/۳۳ کیلوولت اعتبارسنجی شده است. این سیستم راه‌حلی کم‌هزینه و قابل اعتماد برای مشکل خطاهای امپدانس بالا ارائه می‌دهد. در [۲۵]، یک روش طبقه‌بندی نیمه‌نظارت‌شده برای تشخیص خطای امپدانس بالا و سایرحالت‌های گذرا در یک

[Downloaded from jeps.dezful.iau.ir on 2026-11-14]
[DOI: 10.82362/jeps.2025.1.533] Journal of Novel Researches on Smart Power Systems - Vol. 14 - No. 1- Spring 2025

ریزشبکه متصل به سیستم فتوولتائیک پیشنهاد می‌کند. روش پیشنهادی ترکیبی از خوشه‌بندی K-میانگین (بدون نظارت) و الگوریتم شبکه عصبی چندلایه با نظارت است. در مرحله اول، از تکنیک K-میانگین برای شناسایی و حذف نمونه‌های نامرتبط از مجموعه داده‌ها استفاده می شود. سپس، داده‌های خوشه‌بندی شده به‌عنوان ورودی به شبکه عصبی پرسپترون چندلایه[۷] (MLP) داده می‌شوند تا پیش‌بینی نهایی برچسب‌ها انجام شود. این روش ترکیبی نسبت به استفاده جداگانه ازK-میانگین یا شبکه عصبی پرسپترون چندلایه، دقت و نرخ موفقیت بالاتری در تشخیص خطای امپدانس بالا تحت شرایط آزمایش استاندارد و تغییرات آب‌وهوایی فتوولتائیک[۸] (PV) نشان می‌دهد. هم‌چنین، نتایج مطالعه عملکردی نشان می‌دهد که این مدل در مقایسه با روش‌های مستقل، مقاوم‌تر بوده و عملکرد بهتری تحت شرایط عدم قطعیت فتوولتائیک در ریز شبکه‌ها ارائه می‌دهد. مرجع [۲۶]، یک الگوریتم جدید برای تشخیص خطای امپدانس بالا در سیستم‌های توزیع با استفاده از قابلیت‌های برتر تبدیل S ارائه می‌دهد. در این روش، تبدیل S بر روی یک سیکل از سیگنال جریان اعمال شده و اطلاعات زمانی و فرکانسی سیگنال استخراج می‌شود. سپس، چهار شاخص عددی شامل اعوجاج هارمونیک کل، انرژی هارمونیک زوج، ضریب تغییرات و انحراف فاز از خروجی تبدیل S محاسبه می‌شوند. بر اساس مقادیر این شاخص‌ها و برخی آستانه‌های از پیش تعیین‌شده، خطاهای امپدانس بالا از شرایط عادی و سایر رویدادهای سیستم توزیع تشخیص داده می‌شوند. عملکرد این الگوریتم با استفاده از سیگنال‌های شبیه سازی شده توسط نرم‌افزار PSCAD/EMTDC و سیگنال‌های آزمایشی واقعی از یک شبکه توزیع ارزیابی شده است. مرجع [۲۷]، یک روش پیشرفته تشخیص خطاهای امپدانس بالا مبتنی بر یادگیری افزایشی تفسیرپذی[۹] ارائه می‌دهد تا تفسیرپذیری مدل‌های داده‌محور در تشخیص خطا را بهبود بخشد. در این روش، از تبدیل موجک گسسته[۱۰](DWT) برای استخراج ضرایب موجک جریان سمت صفر استفاده شده و با محاسبه انحراف معیار، دید کمی از خطاهای امپدانس بالا ارائه می‌شود. سپس، یک شبکه عصبی مصنوعی با استفاده از یک اصل مبتنی بر رگولاریزاسیون بهبود می‌یابد. این رویکرد، پارامترهای مدل را به‌صورت پویا بهینه کرده و ضمن یادگیری دانش جدید از جریان‌های داده موج‌شکل، از فراموشی دانش قبلی جلوگیری می‌کند. عملکرد روش پیشنهادی با استفاده از داده‌های شبیه‌سازی‌شده توسط پلتفرم نرم افزاری PSCAD/EMTDC و داده‌های واقعی اعتبارسنجی شده است.

این روش‌ها به دلیل توانایی در استخراج ویژگی‌های غیرخطی و جزئیات فرکانسی سیگنال‌ها، عملکرد بهتری در مقایسه با تکنیک‌های سنتی ارائه می‌دهند. در پژوهش‌های دیگر نیز از ابزارهای مشابه مانند تکنیک‌های پیش‌پردازش پیشرفته هم‌چون تبدیل ویگنر–ویل[۱۱] [۲۸] استفاده شده است. با این‌حال، روش‌های تجزیه حالت تجربی و تجزیه حالت تجربی تجمعی کامل با داده کمکی نویز به‌دلیل دقت بالا و قابلیت تطبیق با سیگنال‌های غیرایستا، جایگاه ویژه‌ای در این حوزه دارند. این مطالعات نشان می‌دهند که استفاده از تکنیک‌های تجزیه سیگنال و یادگیری ماشین نقش کلیدی در شناسایی دقیق و سریع خطاهای امپدانس بالا ایفا می‌کند. روش‌های ارائه شده در مقالات گذشته با محدودیت‌هایی نظیر دقت پایین، پیچیدگی‌های ریاضیاتی، و استفاده از روش‌هایی ابتدایی در حوزه استخراج ویژگی مواجه بوده‌اند. این مشکلات ضرورت توسعه روشی با دقت بالا، معیارهای ارزش‌یابی قابل اعتماد را برجسته می‌کنند. چنین روشی باید با استفاده از زبان‌های برنامه‌نویسی و نرم‌افزارهای رایج صنعتی، راه‌حلی عملی و مؤثر برای این مسئله ارائه دهد.

در این مقاله، به‌منظور رفع محدودیت‌ها و بهبود دقت در شناسایی خطاهای امپدانس بالا، از روش تجزیه حالت تجربی مجموعه کامل با نویز تطبیقی[۱۲] (ICEEMDAN) برای استخراج ویژگی‌ها استفاده شده است. این روش، در مقایسه با روش‌های پیشین، توانایی بالایی در تحلیل سیگنال‌های غیرخطی و نویزی نشان می‌دهد. ویژگی‌های استخراج شده از روش پیشنهادی به‌عنوان ورودی الگوریتم جنگل تصادفی[۱۳] (RF) به‌کار گرفته شده و داده‌ها به دو کلاس صفر و یک طبقه‌بندی شده‌اند. از طرفی به‌منظور افزایش کیفیت روش پیشنهادی در این مقاله، ویژگی داده‌ها با استفاده از تجزیه حالت تجربی تجمعی کامل با داده کمکی نویز استخراج شده و مجدد به‌عنوان ورودی به الگوریتم جنگل تصادفی داده می شود. سپس نتایج به‌دست آمده با نتایج روش اصلی مقایسه می‌شود. نتایج نشان می‌دهند که روش پیشنهادی نسبت به روش تجزیه حالت تجربی تجمعی کامل با داده کمکی نویز عملکرد بهتری در دقت شناسایی و تحلیل سیگنال‌های خطاهای امپدانس بالا دارد. این مقایسه در نهایت به انتخاب

[Downloaded from jeps.dezful.iau.ir on 2026-11-14]
[DOI: 10.82362/jeps.2025.1.533] Journal of Novel Researches on Smart Power Systems - Vol. 14 - No. 1- Spring 2025

روش تجزیه حالت تجربی مجموعه کامل با نویز تطبیقی به‌عنوان روش بهینه برای این کاربرد منجر می‌شود. روش پیشنهادی تنها بر روی شبکه تست استاندارد ۳۴ شینه IEEE پیاده سازی شده است. در این پژوهش، از زبان برنامه‌نویسی Python به‌عنوان محیطی شی‌گرا و سطح بالا همراه با نرم‌افزار EMTP-RV استفاده شده است. داده‌های جمع‌آوری‌شده از شبیه‌سازی شبکه تست، پس از پردازش و استخراج ویژگی‌ها، به الگوریتم طبقه‌بندی داده شده و نتایج آن برای ارزیابی دقت و عملکرد روش پیشنهادی تحلیل شده‌اند.

۲- روش تحقیق

در این مقاله، یک روش جدید مبتنی بر تجزیه حالت تجربی مجموعه کامل با نویز تطبیقی برای استخراج ویژگی‌های سیگنال‌های خطاهای امپدانس بالا در شبکه‌های توزیع انرژی الکتریکی پیشنهاد شده است. هدف استفاده از این روش، بهبود دقت شناسایی و کاهش نویز در سیگنال‌ها می‌باشد. در این بخش، مراحل مختلف پردازش داده‌ها، استخراج ویژگی‌ها، و طبقه‌بندی سیگنال‌ها به‌شرح زیر بیان شده است.

مرحله اول: پیش‌پردازش داده‌ها

در ابتدا، داده‌های ورودی به‌دست آمده از سیگنال‌های جریان شبکه‌های توزیع ، برای پردازش آماده می‌شود. این داده‌ها شامل سیگنال‌های جریان خطاهای امپدانس بالا و سایر اختلالات شبکه هستند. پیش‌پردازش شامل فیلترکردن سیگنال‌ها، حذف نویزهای اولیه و تنظیم داده‌ها برای مراحل بعدی است.

مرحله دوم: استخراج ویژگی با استفاده از روش تجزیه حالت تجربی مجموعه کامل با نویز تطبیقی

در این مرحله، از روش پیشنهادی برای تجزیه و تحلیل سیگنال‌ها استفاده شده است. این روش به‌عنوان یک ابزار مؤثر برای استخراج ویژگی از سیگنال‌های غیرخطی و پیچیده شناخته شده است. این روش سیگنال‌های ورودی را به مولفه‌های مختلف[۱۴] (IMF) تجزیه کرده و ویژگی‌های مختلفی مانند انرژی، انحراف معیار و سایر ویژگی‌های آماری از هر مؤلفه استخراج می شود. در ادامه، ویژگی‌های استخراج‌شده برای مراحل طبقه‌بندی استفاده شده است.

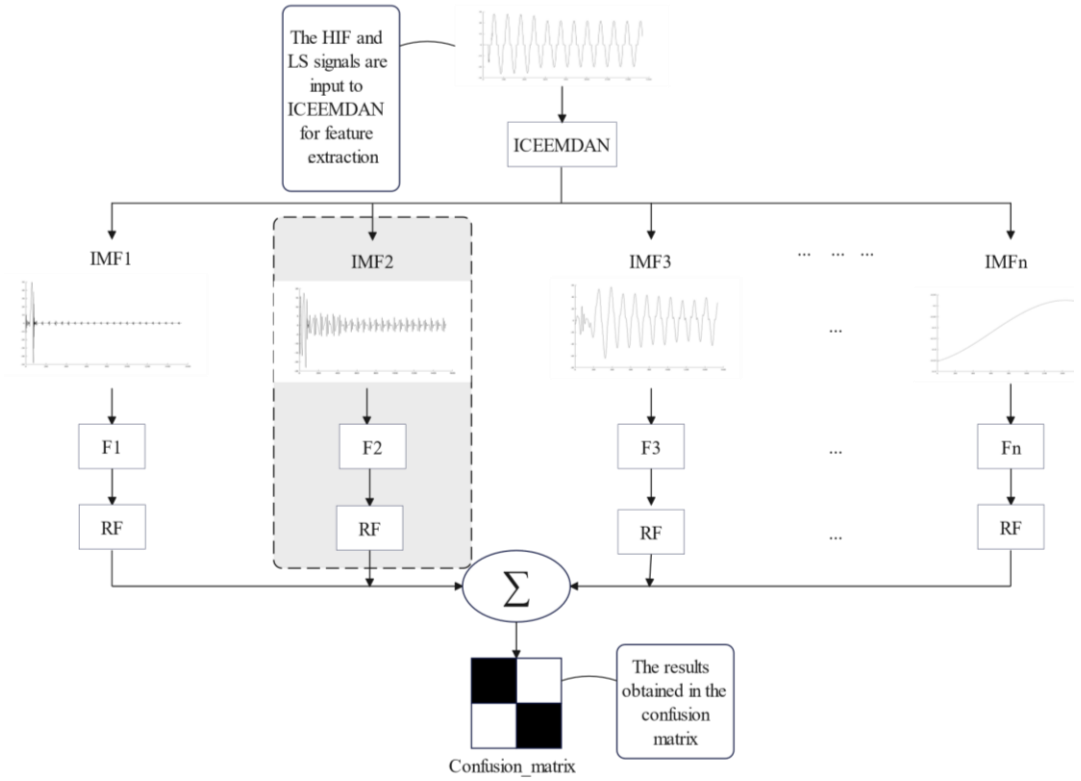
مرحله سوم: طبقه‌بندی با استفاده از الگوریتم جنگل تصادفی

ویژگی‌های استخراج‌شده از روش پیشنهادی به‌عنوان ورودی به الگوریتم جنگل تصادفی داده شده است. این الگوریتم یک روش قدرتمند در طبقه‌بندی داده‌ها می‌باشد که سیگنال‌های خطاهای امپدانس بالا را از سایر اختلالات شبکه تفکیک می‌کند. داده‌ها به دو کلاس صفر (بدون خطا) و یک (خطای امپدانس بالا) تقسیم‌بندی شده و مدل جنگل تصادفی به‌منظور شناسایی خطاها آموزش داده شده است.

مرحله چهارم: ارزیابی عملکرد

برای ارزیابی عملکرد روش پیشنهادی، نتایج طبقه‌بندی با استفاده از معیارهای مختلف ارزیابی مانند دقت، حساسیت، اختصاصیت و امتیاز F1 بررسی شده است. این مقایسه با روش‌های مشابه مانند تجزیه حالت تجربی تجمعی کامل با داده کمکی نویز انجام شده تا برتری روش پیشنهادی به‌طور دقیق‌تر مشخص شود. شکل (۱) شماتیک کلی روش پیشنهادی را نشان می‌دهد.

[Downloaded from jeps.dezful.iau.ir on 2026-11-14]
Journal of Novel Researches on Smart Power Systems - Vol. 14 - No. 1- Spring 2025
[DOI: 10.82362/jeps.2025.1.533]



شکل(۱): شماتیک کلی روش پیشنهادی

Figure (1): General schematic of the proposed method

۲-۱- جمع‌آوری و آماده‌سازی داده‌های ورودی

در این پژوهش از سیگنال‌های جریان برای تشخیص خطاهای امپدانس بالا استفاده شده است. مطالعات صورت گرفته، بر روی شبکه توزیع تست ۳۴ شینه IEEE می‌باشد. مدل پیشنهادی خطای امپدانس بالا به شبکه تست ۳۴ شینه IEEE متصل شده است. سپس سیگنال‌های جریان خطاهای امپدانس بالا به‌عنوان داده به جهت استخراج ویژگی در مرحله بعد، جمع آوری شده است.

۲-۲- روش تجزیه حالت تجربی مجموعه کامل با نویز تطبیقی

تجزیه حالت تجربی مجموعه کامل با نویز تطبیقی یک روش تجزیه سیگنال است که هدف آن کاهش خطاهای تجزیه و تفکیک بهتر مؤلفه‌های سیگنال به اجزای مختلف است. این روش به‌طور خاص برای سیگنال‌های غیرخطی مناسب است. این روش به‌عنوان یک نسخه بهبود یافته از روش تجزیه حالت تجربی تجمعی توسعه یافته است. تجزیه حالت تجربی تجمعی خود نسخه‌ای اصلاح شده از روش تجزیه حالت تجربی می‌باشد. تجزیه حالت تجربی یک روش غیرخطی است که برای تجزیه سیگنال‌های پیچیده به اجزای ساده‌تر و قابل تحلیل استفاده می شود. هدف از تجزیه حالت تجربی این است که یک سیگنال پیچیده را به مجموعه‌ای از مؤلفه‌ها تجزیه کند. این اجزا به‌طور طبیعی ویژگی‌های فرکانسی مختلف سیگنال را نمایان می‌کنند. یکی از ویژگی‌های مهم این روش این است که نیازی به فرضیه‌های اولیه مثل خطی بودن یا ایستایی سیگنال ندارد. روش تجزیه حالت تجربی به‌طور کلی شامل مراحلی هم‌چون استخراج نوسانات مقیاس‌های بالا، استخراج مؤلفه‌ها و باقی‌مانده‌ها تقسیم شده است. روش تجزیه حالت تجربی تجمعی کامل با داده کمکی نویز به‌عنوان نسخه‌ای پیشرفته‌تر از تجزیه حالت تجربی، با هدف کاهش مشکلات نویز و بهبود دقت تجزیه سیگنال‌های پیچیده توسعه یافته است. در این روش، به‌جای اضافه کردن تنها یک نویز به سیگنال، از نویز تصادفی و متعدد استفاده شده است. از ویژگی‌های این روش می‌توان به استفاده از مجموعه‌ای از نویزها و میانگین‌گیری از مؤلفه‌های به‌دست‌آمده اشاره نمود.

[Downloaded from jeps.dezful.iau.ir on 2026-11-14]
[DOI: 10.82362/jeps.2025.1.533]
Journal of Novel Researches on Smart Power Systems - Vol. 14 - No. 1- Spring 2025

روش پیشنهادی یک بهبود دیگر از روش تجزیه حالت تجربی تجمعی کامل با داده کمکی نویز است که به‌طور خاص برای بهبود دقت تجزیه سیگنال‌ها و کاهش اثرات نویز طراحی شده است. تفاوت اصلی این دو روش در نحوه اضافه کردن نویز است. در روش پیشنهادی، نویز به‌صورت آداپتیو یا تطبیقی به سیگنال اضافه می‌شود. این روش شامل ویژگی‌های منحصر به‌فردی می‌باشد. برخلاف روش دیگر که نویز به صورت ثابت به سیگنال‌ها اضافه می شود، در روش پیشنهادی نویز به‌طور آداپتیو و با توجه به ویژگی‌های سیگنال اضافه می‌شود. این نویز به گونه‌ای طراحی شده است که بر اساس ویژگی‌های سیگنال اصلی تغییر می‌کند، که این امر باعث افزایش دقت در استخراج مؤلفه‌ها و کاهش اثرات نویز می‌شود. استفاده از نویز آداپتیو باعث شده است که این روش بتواند بهتر از دیگر روش‌ها، سیگنال‌های پیچیده و دارای نویز را تجزیه کند. این امر به‌ویژه در سیگنال‌هایی که ویژگی‌های متغیر و غیرخطی دارند، مهم است. هم‌چنین اضافه کردن نویز آداپتیو سبب بهبود کیفیت مؤلفه‌ها و کاهش خطا در تحلیل سیگنال شده است. این روش می‌تواند مشکلاتی که در روش‌های قبلی وجود داشت (مانند نویز زیاد یا تجزیه نادرست) را به حداقل برساند. روش پیشنهادی به‌ویژه برای سیگنال‌هایی که رفتار غیرخطی دارند، بسیار مناسب است. این ویژگی روش بیان شده را از دیگر روش‌ها متمایز می‌کند.

پس باید بیان کرد که تجزیه حالت تجربی به‌دلیل سادگی و توانایی در تجزیه سیگنال‌های پیچیده، به‌طور گسترده‌ای استفاده می شود اما به‌دلیل حساسیت زیاد به نویز و مشکلات در تفکیک مؤلفه‌ها، محدودیت‌هایی دارد. از طرفی تجزیه حالت تجربی تجمعی کامل با داده کمکی نویز این مشکلات را با استفاده از نویزهای تصادفی متعدد حل کرده و دقت تجزیه را بهبود می‌بخشد، اما هم‌چنان با مشکلات نویزهایی که به‌صورت ثابت به سیگنال‌ها اضافه می‌شود، مواجه است. در نهایت روش تجزیه حالت تجربی مجموعه کامل با نویز تطبیقی به‌عنوان پیشرفته‌ترین نسخه، با استفاده از نویز آداپتیو و بهینه‌سازی فرآیند تجزیه، بهترین دقت را در تحلیل سیگنال‌های پیچیده و دارای نویز فراهم می‌کند. رابطه (۱) ترکیب سیگنال اصلی و نویز تصادفی را نشان می‌دهد.

$$\eta(t) + x(t) = y(t) \quad (۱)$$

که در آن، $y(t)$ سیگنال با نویز، $x(t)$ سیگنال اصلی و $\eta(t)$ نویز تصادفی می‌باشد.

با استفاده از تجزیه حالت تجربی، سیگنال $y(t)$ به مجموعه‌ای از مؤلفه‌ها تجزیه می‌شود. در این مرحله، سیگنال به مؤلفه‌هایی با فرکانس‌های مختلف تقسیم می‌شود. رابطه کلی (۲) برای تجزیه به مؤلفه‌ها به قرار زیر است.

$$r_n(t) + \mathrm{IMF}_i(t) \sum_{i=1}^{n} = x(t) \quad (۲)$$

که در آن، $x(t)$ سیگنال اصلی، $\mathrm{IMF_i(t)}$ مؤلفه‌های درونی و $\mathrm{r_n(t)}$ باقی مانده است که به‌عنوان روند نهایی سیگنال درنظر گرفته شده است.

در ادامه مجموعه‌ای از نویزها که به‌طور موازی چندین بار نویزهای مختلف را به سیگنال اصلی اضافه می‌کند و فرآیند تجزیه حالت تجربی را برای هر بار اضافه کردن نویز تکرار می‌کند، اعمال شده است. این فرآیند به‌طور کلی برای چندین مجموعه از نویزها انجام می‌شود. پس از انجام تجزیه سیگنال برای مجموعه‌های مختلف از نویزها میانگین مؤلفه‌های به‌دست آمده محاسبه می‌شود تا مؤلفه‌های نهایی با دقت بیش‌تری استخراج شود. رابطه (۳) این موضوع را نشان می‌دهد.

$$IMF_i^n(t) \sum_{n=1}^{N} \frac{1}{N} = IMF_i^{final}(t) \quad (۳)$$

که در آن، $\mathrm{IMF_i^{final}(t)}$ نیز مؤلفه‌های تجزیه حالت تجربی نهایی، $\mathrm{IMF_i^n(t)}$ در n-امین نمونه از نویز و N تعداد نمونه‌های نویز است.

از ویژگی‌های روش پیشنهادی می‌توان به کاهش نویز (توانایی کاهش نویزهای موجود در سیگنال)، دقت بیش‌تر در استخراج مؤلفه‌ها (به‌دلیل استفاده از میانگین‌گیری بر روی چندین تجزیه، دقت استخراج مؤلفه‌ها بهبود می‌یابد) و مناسب برای سیگنال‌های غیرخطی و پیچیده (به‌ویژه برای سیگنال‌هایی که دارای رفتار غیرخطی هستند، مناسب است.) اشاره نمود.

[Downloaded from jeps.dezful.iau.ir on 2026-11-14]
Journal of Novel Researches on Smart Power Systems - Vol. 14 - No. 1- Spring 2025
[DOI: 10.82362/jeps.2025.1.533]

۲-۲-۱- اعمال روش پیشنهادی برای سیگنال خطای امپدانس بالا

برای اســـتخراج ویژگی‌های ســـیگنال خطای امپدانس بالا، ابتدا ســـیگنال‌های ولتاژ و جریان که حاوی خطاهای امپدانس بالا هســـتند، تحت تجزیه حالت تجربی مجموعه کامل با نویز تطبیقی قرار می‌گیرند. در مرحله اول، ســـیگنال‌های ورودی از شـــبکه توزیع که شـــامل ســـیگنال‌های خطاهای امپدانس بالا هســـتند، وارد فرآیند تجزیه حالت تجربی مجموعه کامل با نویز تطبیقی می‌شـــوند. این ســـیگنال‌ها به مجموعه‌ای از مؤلفه‌ها تجزیه می‌شـــوند. در مرحله دوم، انتخاب مؤلفه مناســـب از میان مؤلفه‌های استخراج شده، برای استخراج ویژگی‌ها از مؤلفه‌های دوم استفاده می شود. دلیل انتخاب مؤلفه‌های دوم این است که این مؤلفه معمولاً شامل ویژگی‌های مهم و نوسانات متوسط سیگنال‌های خطاهای امپدانس بالا است که می‌تواند اطلاعات مفیدی در مورد خطا ارائه دهد.

۲-۲-۲- استخراج ویژگی‌ها از مولفه‌های دوم

پس از استخراج مؤلفه‌های دوم از سیگنال‌های خطاهای امپدانس بالا، ویژگی‌های مختلفی از آن استخراج می شود. ویژگی‌هایی که در این تحقیق استخراج می‌شوند، شامل موارد زیر هستند:

میانگین دامنه[۱۵]

میانگین دامنه یک ویژگی ساده است که معمولاً برای سیگنال‌های با نوسانات کوچک یا بدون نوسانات بزرگ استفاده می‌شود. این ویژگی میزان "میانگین" سیگنال را با در نظرگرفتن مقادیر مطلق سیگنال اندازه‌گیری می‌کند. به‌عبارت دیگر، این ویژگی میزان حرکت سیگنال را بدون توجه به علامت آن (مثبت یا منفی بودن) اندازه‌گیری می‌کند. رابطه (۴) میانگین دامنه را نشان می‌دهد.

$$|x_i| \sum_{i=1}^{N} \frac{1}{N} = \ Mean\ Amplitude \qquad (۴)$$

که در آن x_i هر نقطه از سیگنال مؤلفه‌های دوم و N تعداد نقاط سیگنال است. به‌عبارتی $|x_i|$ مقدار مطلق هر نقطه از سیگنال است که به‌طور مستقیم نشان دهنده اندازه نوسانات در سیگنال می‌باشد. این ویژگی برای شناسایی سیگنال‌های با رفتار نوسانی استفاده می شود. سیگنال‌های خطاهای امپدانس بالا معمولاً دارای نوسانات بزرگ و شدید هستند که می‌توانند به‌طور ناگهانی تغییر کنند. میانگین دامنه به‌طور مستقیم می‌تواند شدت این نوسانات را اندازه‌گیری کند. سیگنال‌های خطاهای امپدانس بالا دارای دامنه بزرگ و تغییرات واضح هستند، و این ویژگی می‌تواند به شناسایی نوسانات خاص در این سیگنال‌ها کمک کند.

انرژی[۱۶]

انرژی سیگنال به‌طور معمول به‌عنوان معیاری برای اندازه‌گیری قدرت سیگنال در یک بازه زمانی خاص است. این ویژگی به‌ویژه در تحلیل سیگنال‌هایی که در آن‌ها سیگنال‌های پرقدرت مهم هستند، مفید است. انرژی یک سیگنال معمولاً به‌عنوان مجموع مربعات سیگنال محاسبه می‌شود که در رابطه (۵) نشان داده شده است.

$$x_i^2 \sum_{i=1}^{N} = \ \text{Energy} \qquad (۵)$$

که در آن x_i^2 هر نقطه از سیگنال مؤلفه‌های دوم است. انرژی سیگنال در شناسایی خطاهای امپدانس بالا بسیار مهم است، زیرا این خطاها باعث افزایش ناگهانی قدرت سیگنال می شوند. اندازه‌گیری انرژی می‌تواند به‌راحتی سیگنال‌های خطاهای امپدانس بالا را از سیگنال‌های نرمال جدا کند، زیرا خطاهای امپدانس بالا معمولاً دارای انرژی بیش‌تری نسبت به سیگنال‌های معمولی هستند. این ویژگی می‌تواند تغییرات ناگهانی در قدرت سیگنال را شناسایی کرده و به تشخیص صحیح این خطا کمک کند.

انحراف معیار[۱۷]

انحراف معیار یک معیار آماری اســـت که میزان پراکندگی یا پراش ســـیگنال را از میانگین آن اندازه‌گیری می‌کند. این ویژگی به‌شدت برای تحلیل سیگنال‌های با نوسانات بزرگ یا کوچک و شناسایی تغییرات در سیگنال‌های خطاهای امپدانس بالا مفید

[Downloaded from jeps.dezful.iau.ir on 2026-11-14]
[DOI: 10.82362/jeps.2025.1.533]
Journal of Novel Researches on Smart Power Systems - Vol. 14 - No. 1- Spring 2025

است. هرچه انحراف معیار بزرگ‌تر باشد، یعنی سیگنال بیش‌تر از مقدار میانگین خود تغییر کرده است. رابطه (۶) انحراف معیار را نشان می‌دهد.

$$\sqrt{(x_i-\mu)^2\sum_{i=1}^{N}\frac{1}{N}}=\text{StdDev} \qquad (۶)$$

که در آن μ میانگین سیگنال است. تغییرات ناگهانی و زیاد در سیگنال‌های خطاهای امپدانس بالا معمولاً باعث افزایش انحراف معیار می شوند. این ویژگی قادر است نوسانات زیاد سیگنال را که معمولاً در اثر وقوع این خطا ایجاد می شود، شناسایی کند. بنابراین، انحراف معیار یک شاخص کلیدی در تشخیص خطاهایی است که با نوسانات شدید همراه هستند.

پیک تا پیک[۱۸]

ویژگی پیک تا پیک نشان‌دهنده تفاوت بین بزرگ‌ترین و کوچک‌ترین مقدار در سیگنال است. این ویژگی برای شناسایی نوسانات شدید در سیگنال خطای امپدانس بالا اهمیت دارد. اگر در یک سیگنال تغییرات ناگهانی و بزرگ رخ دهد، این ویژگی قادر به اندازه‌گیری آن است. رابطه (۷) مقدار پیک تا پیک را نشان می‌دهد.

$$min(x)-max(x)=Peak_to_Peak \qquad (۷)$$

که در آن به‌ترتیب$\max(x)$ بزرگ‌ترین و $\min(x)$ کوچک‌ترین مقدار سیگنال می‌باشد. این ویژگی می‌تواند تفاوت بین بزرگ‌ترین و کوچک‌ترین مقادیر سیگنال را اندازه‌گیری کند. در سیگنال‌های خطاهای امپدانس بالا، تغییرات ناگهانی و بزرگ معمولاً باعث افزایش مقدار پیک تا پیک می‌شوند. این ویژگی به شناسایی نوسانات شدید و غیرمنتظره که ممکن است نشان‌دهنده خطاهای امپدانس بالا باشند، کمک می‌کند.

چولگی[۱۹]

چولگی یکی از ویژگی‌های آماری است که میزان عدم تقارن توزیع یک سیگنال حول میانگین آن را اندازه‌گیری می‌کند. اگر چولگی مثبت باشد، به این معنی است که توزیع سیگنال به سمت راست کشیده شده است، و اگر چولگی منفی باشد، توزیع به سمت چپ کشیده شده است. رابطه (۸) چولگی را نشان می‌دهد.

$$\left(\frac{x_i-\mu}{\sigma}\right)^3\sum_{i=1}^{N}\frac{N}{(N-2)(N-1)}=\text{Skewness} \qquad (۸)$$

که در آن، μمیانگین سیگنال، σ انحراف معیار سیگنال، x_i هر نقطه از سیگنال مولفه‌های دوم و N تعداد نقاط سیگنال است. در سیگنال‌های خطای امپدانس بالا، توزیع سیگنال‌ها به‌طور معمول از حالت متقارن خارج می‌شود. چولگی می‌تواند به‌خوبی عدم تقارن توزیع سیگنال‌های خطا را نشان دهد و به شناسایی سریع سیگنال‌های غیرطبیعی و خطاهای احتمالی کمک کند. سیگنال‌های خطای امپدانس بالا معمولاً دارای چولگی مثبت یا منفی هستند که با نوسانات غیرقابل پیش‌بینی ایجاد می‌شوند.

کشیدگی[۲۰]

کشیدگی یک ویژگی آماری است که میزان "نوک‌داری" یا "پهنای" توزیع سیگنال را اندازه‌گیری می‌کند. کشیدگی بالا نشان‌دهنده توزیع‌های با پیک‌های تیز است، در حالی‌که کشیدگی پایین نشان‌دهنده توزیع‌های پهن‌تر و صاف‌تر است. رابطه (۹) کشیدگی را نشان می‌دهد.

$$\frac{(N-1)^2 3}{(N-3)(N-2)}-\left(\frac{x_i-\mu}{\sigma}\right)^4\sum_{i=1}^{N}\frac{N(N+1)}{(N-3)(N-2)(N-1)}=\text{Kurtosis} \qquad (۹)$$

کشیدگی می‌تواند پیک‌های تیز و نوک‌دار در سیگنال‌ها را شناسایی کند که در سیگنال‌های خطاهای امپدانس بالا به‌طور خاص مشاهده می‌شود. این سیگنال‌ها معمولاً ویژگی‌های کشیدگی بالاتری دارند که نشان‌دهنده تغییرات ناگهانی و پرقدرت هستند. این ویژگی می‌تواند به شناسایی دقیق‌تر خطاها و بررسی رفتار غیرعادی سیگنال‌ها کمک کند.

[Downloaded from jeps.dezful.iau.ir on 2026-11-14]
[DOI: 10.82362/jeps.2025.1.533]
Journal of Novel Researches on Smart Power Systems - Vol. 14 - No. 1- Spring 2025

تمامی ویژگی‌های ذکر شده از سیگنال مؤلفه‌های دوم، که حاصل از پردازش روش تجزیه حالت تجربی مجموعه کامل با نویز تطبیقی هستند، به‌طور کلی برای شناسایی خصوصیات خاص سیگنال‌های خطاهای امپدانس بالا استخراج می شوند. به‌ویژه، ویژگی‌هایی مانند انرژی، انحراف معیار، و پیک تا پیک می‌توانند نوسانات بزرگ و تغییرات ناگهانی موجود در این نوع از خطاها را شناسایی کنند. هم‌چنین ویژگی‌های چولگی و کشیدگی می‌توانند به شناسایی توزیع غیرطبیعی و ناهنجاری‌های سیگنال‌های خطاهای امپدانس بالا کمک کنند.

این ویژگی‌ها به‌عنوان ورودی برای الگوریتم‌های یادگیری ماشین استفاده شده است تا سیگنال‌های خطاهای امپدانس بالا از سیگنال‌های نرمال جدا شود. به این ترتیب، استخراج ویژگی‌ها از سیگنال‌های مؤلفه‌های دوم و استفاده از آن‌ها در فرآیند یادگیری ماشین، به‌طور مؤثر می‌تواند به شناسایی و تشخیص خطا کمک کند. این ویژگی‌ها برای شناسایی دقیق‌تر و کارآمدتر خطا در شبکه‌های توزیع انرژی الکتریکی استفاده می شوند و به‌عنوان ابزارهای مهم در تحلیل سیگنال‌های خطاهای امپدانس بالا عمل می‌کنند.

۲-۳- الگوریتم جنگل تصادفی

الگوریتم جنگل تصادفی یکی از معروف‌ترین و پرکاربردترین الگوریتم‌های یادگیری ماشین در مسائل طبقه‌بندی و رگرسیون است. این الگوریتم به‌ویژه در مسائل پیچیده‌ای که داده‌ها دارای ویژگی‌های غیرخطی یا روابط پیچیده هستند، عملکرد بسیار خوبی دارد.

۲-۳-۱- تعریف الگوریتم جنگل تصادفی

جنگل تصادفی یک روش مبتنی بر تجمع است که از مجموعه‌ای از درخت‌های تصمیم‌گیری استفاده می‌کند. در این الگوریتم، به‌جای استفاده از یک درخت تصمیم‌گیری واحد، چندین درخت تصمیم‌گیری به‌طور مستقل ساخته می‌شوند و پیش‌بینی‌ها از طریق رأی‌گیری اکثریت یا میانگین‌گیری از پیش‌بینی‌های درخت‌ها انجام می شود. این فرآیند باعث کاهش خطر بیش‌برازش[۲۱] و بهبود دقت مدل می‌شود.

۲-۳-۲- دلایل انتخاب الگوریتم جنگل تصادفی

الگوریتم جنگل تصادفی برای مسائل طبقه‌بندی سیگنال‌ها در این تحقیق انتخاب شده است. از دلایل انتخاب این الگوریتم می‌توان به دقت بالا، قابلیت تحمل داده‌های نویزی، ساده بودن و قابل فهم بودن مدل و قابلیت پردازش ویژگی‌های زیاد اشاره نمود.

به‌دلیل محدودیت‌ها و پایداری ضعیف طبقه‌بندهای تکی، افزایش دقت طبقه‌بندی در مواجهه با شرایط خاص دشوار است. الگوریتم جنگل تصادفی از مجموعه‌ای از درخت‌های تصمیم‌گیری تشکیل شده است. جنگل‌های تصادفی، با توانایی تعمیم‌دهی و دقت بالا، یک الگوریتم ترکیبی است که توسط لئو بریمن در سال ۲۰۰۱ ارائه شد [۲۹]. این الگوریتم، ایده "جمع‌آوری بوت-استرپ" بریمن را با روش "زیرفضای تصادفی" هو ترکیب کرده و با ادغام چندین مدل درخت تصمیم[۲۲] دقت پیش‌بینی را بهبود می‌بخشد. با استفاده از نتایج تصمیم‌گیری چندین مدل درخت تصمیم، خروجی نهایی با رأی‌گیری کلیه درخت‌های تصمیم تعیین می‌شود به‌عبارت دیگر، هدف الگوریتم این است که یک مدل ترکیبی از درخت‌های تصمیم‌گیری بسازد و پیش‌بینی نهایی را از طریق رأی‌گیری یا میانگین‌گیری انجام دهد. برای هر درخت تصمیم‌گیری، یک نمونه تصادفی از داده‌های آموزشی انتخاب می شود. برای هر درخت تصمیم‌گیری در هر گره، ویژگی‌ها به‌طور تصادفی انتخاب می شوند تا تصمیم‌گیری براساس آن‌ها انجام شود. درخت تصمیم‌گیری به‌طور تکراری گره‌ها را تقسیم می‌کند تا در نهایت به برگ‌هایی برسد که پیش‌بینی نهایی را ارائه دهد.

درخت تصمیم تصادفی، کوچک‌ترین واحد تصمیم‌گیری است که یک جنگل تصادفی را تشکیل می‌دهد. تولید آن بر اساس دو ویژگی تصادفی خلاصه می شود: نمونه‌های آموزشی تصادفی هر درخت تصمیم با روش بگینگ تولید می شوند و ویژگی‌های نمونه‌های آموزشی به صورت تصادفی برای تقسیم گره‌های درخت تصمیم انتخاب می شوند [۳۰]. مراحل ساخت جنگل‌های تصادفی به‌شرح زیر است:

[Downloaded from jeps.dezful.iau.ir on 2026-11-14]
[DOI: 10.82362/jeps.2025.1.533] Journal of Novel Researches on Smart Power Systems - Vol. 14 - No. 1- Spring 2025

الف) ایجاد مجموعه آموزشی با روش بوت استرپ:

از روش بوت استرپ برای نمونه‌گیری مجدد و ایجاد یک مجموعه آموزشی برای هر درخت تصمیم استفاده می‌شود. فرض کنید مجموعه‌ای شامل نمونه مختلف $\{C_1, C_2, \dots C_N\}$ باشد. اگر یک نمونه از مجموعه با جای‌گذاری انتخاب شود و این فرآیند بارها تکرار شود تا مجموعه جدید W^* تشکیل شود، احتمال این‌که مجموعه جدید شامل یک نمونه خاص نباشد $c_r(r = 1,2, \dots n)$ برابر است با روابط (۱۰) و (۱۱).

$$p = \left(1 - \frac{1}{n}\right)^n \quad (۱۰)$$

$$\lim_{n\to\infty} p = \lim_{n\to\infty} \left(1 - \frac{1}{n}\right)^n = e^{-1} \approx 0.368 \quad (۱۱)$$

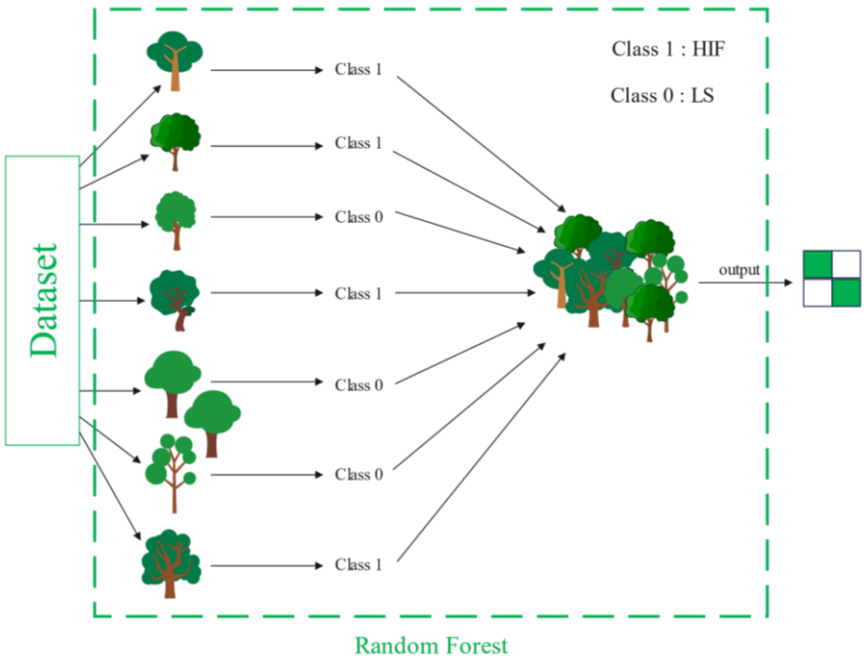
بنابراین، ۳۶/۸ درصد از نمونه‌ها انتخاب نخواهند شد. این امر موجب می‌شود که درخت تصمیم در جنگل تصادفی به یک حل بهینه محلی نرسد و داده‌های غیرعادی به‌طور مؤثر از ورود به مجموعه نمونه جلوگیری شوند.

ب) ساخت هر درخت تصمیم:

قبل از انتخاب ویژگی‌ها در هر گره غیر برگ، $q(q < Q)$ ویژگی به‌صورت تصادفی از میان ویژگی‌های Q استخراج شده و به‌عنوان مجموعه ویژگی‌های طبقه‌بندی گره فعلی انتخاب می‌شود. گره در بهترین حالت ممکن میان این q ویژگی تقسیم شود. با تقسیم گره‌ها، یک درخت تصمیم کامل ایجاد می‌شود. هر درخت تصمیم بدون هرس رشد می‌کند تا به گره‌های برگ برسد. با استفاده از هر مجموعه آموزشی، یک درخت تصمیم متناظر تولید می‌شود.

ج) تشکیل جنگل تصادفی:

از درخت‌های تصمیم ساخته‌شده برای آزمایش نمونه‌ها استفاده می‌شود. خروجی دسته‌بندی هر درخت تصمیم جمع‌بندی شده و دسته‌ای که بیش‌ترین تعداد خروجی را دارد به‌عنوان دسته نمونه آزمایشی تعیین می‌شود. ساختار جنگل تصادفی در شکل (۲) نشان داده شده است.



شکل(۲): ساختار جنگل تصادفی

Figure (2): Random forest structure

[Downloaded from jeps.dezful.iau.ir on 2026-11-14]

Journal of Novel Researches on Smart Power Systems - Vol. 14 - No. 1- Spring 2025
[DOI: 10.82362/jeps.2025.1.533]

۲-۳-۳- نحوه پیاده‌سازی الگوریتم جنگل تصادفی در حل مسئله

برای طبقه‌بندی سیگنال‌های استخراج‌شده و تشخیص خطای امپدانس بالا از تغییرات بار، در این مقاله از الگوریتم جنگل تصادفی به‌عنوان یک طبقه‌بند قدرتمند استفاده گردید. در ادامه، نحوه پیاده‌سازی این الگوریتم تشریح می‌شود.

الف) آماده‌سازی داده‌ها

ابتدا داده‌های سیگنال با استفاده از روش‌های استفاده شده به‌منظور استخراج ویژگی و از هر سیگنال مجموعه‌ای از شش ویژگی (F1 تا F6) استخراج شده است. ویژگی‌ها به‌همراه برچسب درنظر گرفته شده به‌عنوان ورودی طبقه‌بندی مورد استفاده قرار گرفته شده است. پیش از اعمال الگوریتم، داده‌ها نرمال‌سازی و به دو بخش داده‌های آموزش و آزمون تقسیم شده است.

همان‌طورکه اشاره شد، الگوریتم جنگل تصادفی مبتنی بر ایجاد تعداد زیادی درخت تصمیم است. برای هر درخت یک زیرمجموعه تصادفی از داده‌ها با روش Bootstrap انتخاب شده است. در هر گره، تنها تعدادی از ویژگی‌ها به‌صورت تصادفی در نظر گرفته شده است تا تقسیم‌بندی انجام شود. معیار انتخاب تقسیم، شاخص جینی در نظر گرفته شده است. این فرآیند تا رسیدن به عدم بهبود در دقت ادامه یافته است. پس از آموزش هر درخت، طبقه‌بندی نهایی با روش رأی‌گیری اکثریت میان خروجی‌های درخت‌ها تعیین شده است. بدین ترتیب، برای هر نمونه ورودی، طبقه‌ای انتخاب شد که بیش‌ترین رأی را از درخت‌های مختلف دریافت کرده است. در انتها، مدل آموزش‌دیده با استفاده از داده‌های آزمون مورد ارزیابی قرار گرفت. معیارهای دقت، حساسیت، دقت پیش‌بینی، امتیاز F1 و ... محاسبه گردید تا کارایی الگوریتم در تشخیص خطای امپدانس بالا سنجیده شود.

۳- معیار ارزیابی (ماتریس درهم ریختگی):

معیار ارزیابی در این مقاله ماتریس درهم‌ریختگی می‌باشد. این ماتریس، کیفیت عملکرد طبقه‌بندی و کلاس بندی‌های مجموعه داده‌های ورودی را نمایش می‌دهد. این معیار معمولا در الگوریتم های طبقه بندی بسیار پرکاربرد است و به‌عنوان یک معیار اصلی در ارزیابی نتایج استفاده می‌شود. شکل (۳) پارامترهای ماتریس درهم‌ریختگی را نمایش می‌دهد.

		مقادیر واقعی	
		مثبت	منفی
مقادیر تشخیص داده شده	مثبت	مثبت درست TP	مثبت نادرست FP
	منفی	منفی نادرست FN	منفی درست TN

شکل(۳): پارامترهای ماتریس درهم ریختگی

Figure (3): Confusion matrix parameters

همان‌طور که مشاهده می‌شود، ماتریس درهم ریختگی از چهار سلول تشکیل شده است. هدف اصلی ما در این پژوهش شناسایی خطای امپدانس بالا می باشد. برای شناسایی این خطا با توجه به ماتریس درهم ریختگی، اگر تشخیص مثبت باشد، به این معنی است که خطای امپدانس بالا رخ داده است و اگر خلاف آن باشد و به‌عبارتی تشخیص منفی باشد، به این معنی است که خطای امپدانس بالا رخ نداده است. هر کدام از سلول‌های این ماتریس دارای یکسری مفاهیم می‌باشد که در زیر به‌ترتیب به آن‌ها پرداخته شده است:

[Downloaded from jeps.dezful.iau.ir on 2026-11-14]
[DOI: 10.82362/jeps.2025.1.533]
Journal of Novel Researches on Smart Power Systems - Vol. 14 - No. 1- Spring 2025

- مثبت درست[۲۳] : در این حالت خطای امپدانس بالا رخ داده است و الگوریتم هم پیش‌بینی درستی داشته است.
- منفی در ست[۲۴] : در این حالت خطای امپدانس بالا رخ نداده ا ست و الگوریتم هم به‌همین مو ضوع ا شاره کند و عدم ایجاد خطا را اعلام کرده است.
- مثبت نادرست[۲۵] : در این حالت خطای امپدانس بالا رخ نداده است اما الگوریتم وقوع خطا را تشخیص داده است.
- منفی نادرست[۲۶] : در این حالت خطای امپدانس بالا رخ داده است اما الگوریتم عدم وقوع خطا را بیان کرده است.

بر اســـاس تعاریفی که از ســـلول‌های ماتریس درهم‌ریختگی داریم، می‌توانیم روابط حاکم بر معیارهای ارزش‌یابی در مســـائل طبقه‌بندی را بیان کنیم. در این پژوهش از شش معیار حساسیت[۲۷]، دقت (نسبت مقادیر اندازه‌گیری شده نسبت به یک مقدار خاص)[۲۸]، اختصاصیت[۲۹]، دقت (نزدیکی مقادیر اندازه‌گیری شده نسبت به یکدیگر)[۳۰]، امتیاز F[۳۱] و ضریب تشابه[۳۲] استفاده شده است. که روابط مربوطه این معیارها در(۱۲) تا (۱۷) نشان داده شده است.

$$Sensitivity = \frac{TP}{TP + FN} \times 100\% \quad (۱۲)$$

$$Accuracy = \frac{TP + TN}{TP + FN + FP + TN} \times 100\% \quad (۱۳)$$

$$Specificity = \frac{TN}{TN + FP} \times 100\% \quad (۱۴)$$

$$Precision = \frac{TP}{TP + FP} \times 100\% \quad (۱۵)$$

$$F1 - Score = \frac{2 * (Precision * Sensitivity)}{Precision + Sensitivity} \times 100\% \quad (۱۶)$$

$$Dice = \frac{2 \times TP}{2 \times TP + FP + FN} \times 100\% \quad (۱۷)$$

شبکه توزیع انرژی الکتریکی مورد مطالعه

در این مقاله از شـبکه توزیع برق اسـتاندارد ۳۴ شـینه IEEE اسـتفاده شـده اسـت. شـبکه تسـت دارای ولتاژ نامی در سـطح ۲۴/۹کیلوولت و هم‌چنین دارای فرکانس نامی ۶۰ هرتز می‌باشـــد. نزدیکی ســـطح ولتاژ به شـــبکه واقعی و هم‌چنین تنوع در تجهیزاتی هم‌چون بانک‌های‌خازنی و از طرفی بارهای مختلف از دلایل اصلی انتخاب این شبکه می‌باشد. این موارد شبکه تست ۳۴ شینه IEEE را به یکی از رایج‌ترین شبکه های قدرت آزمایشی برای مطالعات در حوزه تشخیص خطای امپدانس بالا تبدیل کرده است.

۴- نتایج و تحلیل شبیه سازی

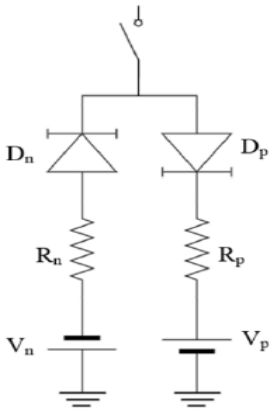
در این مقاله به‌منظور ارزیابی نتایج به‌دست آمده، از شش معیار حساسیت، دقت، شفافیت (وضوح)، ظرافت، امتیازF و ضریب تشابه استفاده شده است.

۴-۱- جمع آوری داده

یکی از مهم‌ترین قسمت‌ها در جمع‌آوری داده‌ها، مدل سازی دقیق خطای امپدانس بالا می‌باشد. مدل خطا باید دارای یک سری ویژگی‌های کلی اعم از غیرخطی بودن، نامتقارن بودن، غیر ایســتا بودن و ... باشـد. به‌همین منظور، در این مقاله از مدل خطای امپدانس بالا امانوئل در مرجع [۳۱] نیز استفاده شده است. شکل (۵) مدل خطای امپدانس بالا استفاده شده در این پژوهش را

[Downloaded from jeps.dezful.iau.ir on 2026-11-14]
[DOI: 10.82362/jeps.2025.1.533] Journal of Novel Researches on Smart Power Systems - Vol. 14 - No. 1- Spring 2025

نشان می‌دهد. این مدل از جفت‌های دیودی، مقاومت و منابع ولتاژ جریان مستقیم تشکیل شده است که در مدار در دو مسیر و به‌شکل معکوس نسبت به‌هم قرار گرفته است. برای نیم سیکل مثبت در این مدل، زمانی که ولتاژ خط از ولتاژ جریان مستقیم بیش‌تر می شود، دیود شروع به هدایت می‌کند. کنترل جریان از طریق مقاومتی که در م سیر وجود دارد انجام می شود. همین روند برای نیم ســـیکل منفی معکوس می‌شـــود. . جدول (۱) پارامترهای مدل خطاهای امپدانس بالا و محدوده تغییرات مقادیر پارامترهای بیان شده در مدل خطای امپدانس بالا انتخاب شده را نشان می‌دهد. شکل (۴) نمونه‌ای از سیگنال جریان خطاهای امپدانس بالا به‌دســـت آمده در نرم‌افزار EMTP-rv را نشـــان می‌دهد. محل خطاهای امپدانس بالا و تغییرات بار در شـــکل (۷) نمایش داده شده ا ست. هم‌چنین جریان خطا تو سط آمپرمتر در ابتدای فیدر اندازه‌گیری شده ا ست. فرکانس نمونه‌برداری در شبکه تست، ۷۶۸۰ هرتز می‌باشد.

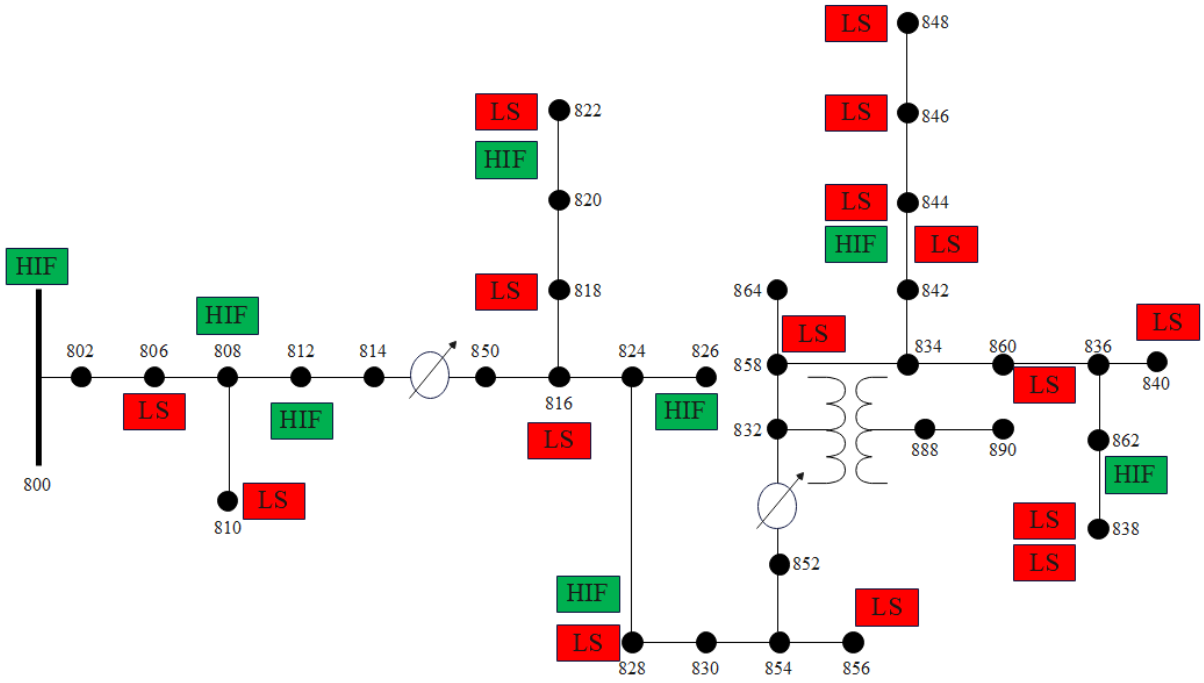


شکل(۴): مدل خطای امپدانس بالا استفاده شده در این پژوهش
Figure (4): HIF model used in this research

Title (1):Parameters of high impedance fault model
جدول(۱): پارامتر های مدل خطای امپدانس بالا

پارامتر های مدل خطای امپدانس بالا	محدوده تغییرات مدل خطای امپدانس بالا
V_P	۴۰۰-۸۰۰ ولت
V_n	۵۰۰-۱۴۰۰ ولت
R_p	۹۰-۸۰۰۰ اهم
R_n	۹۰-۸۰۰۰ اهم
D_p	۰/۷ ولت
D_n	۰/۷ ولت

[Downloaded from jeps.dezful.iau.ir on 2026-11-14]
Journal of Novel Researches on Smart Power Systems - Vol. 14 - No. 1- Spring 2025
[DOI: 10.82362/jeps.2025.1.533]



شکل(۵): نمودار تک‌خطی شبکه استاندارد ۳۴ شینه IEEE

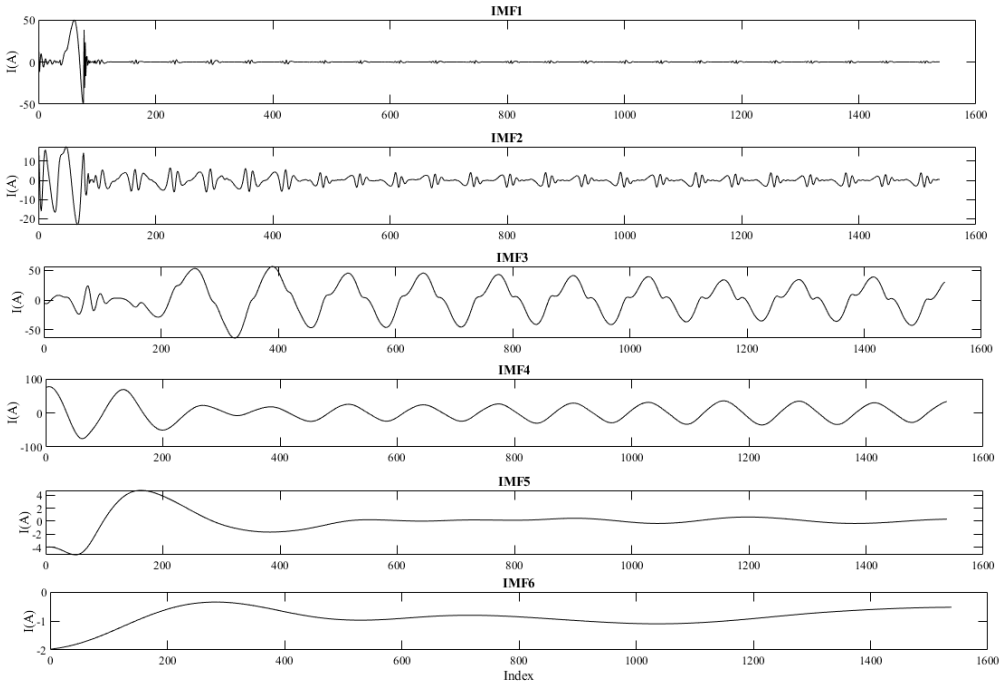
Figure (5): Single-line diagram of the IEEE standard 34-bus network

۴-۲- استخراج ویژگی

استخراج ویژگی در محیط برنامه‌نویسی Google Colab و با استفاده از زبان برنامه‌نویسی پایتون انجام شده است. در این پژوهش، سیگنال‌های خطای امپدانس بالا و تغییرات بار با استفاده از روش پیشنهادی تجزیه و تحلیل شده است. این روش به‌دلیل توانایی بالای آن در تفکیک سیگنال‌های غیرخطی و غیرایستا، به‌عنوان ابزار اصلی انتخاب شد. پس از اعمال روش، سیگنال‌ها به چندین مؤلفه ذاتی تفکیک شده است. مؤلفه‌های ذاتی به‌دست آمده پس از اعمال روش برای سیگنال خطاهای امپدانس بالا و تغییرات بار در شکل‌های (۶) و (۷) نمایش داده شده است.

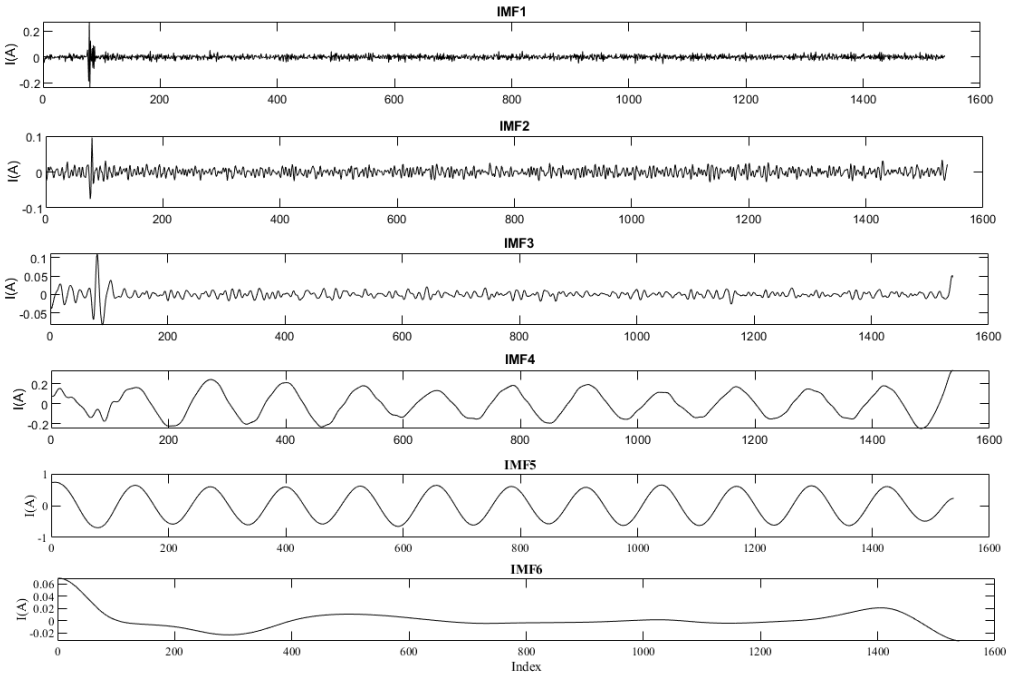
از میان این مؤلفه‌ها، مؤلفه‌های دوم به‌عنوان سیگنال هدف برای استخراج ویژگی انتخاب شد. مؤلفه‌های دوم شامل اطلاعات فرکانسی میانی است که نه‌تنها نویزهای فرکانس بالا (مؤلفه‌های اولیه) را حذف کرده، بلکه از تلفیق بیش‌ازحد سیگنال‌ها در مؤلفه‌های پایین‌تر جلوگیری کرده است. حساسیت به تغییرات خطا از دلایل انتخاب این مؤلفه ذاتی می‌باشد. تحلیل‌ها نشان داده است که مؤلفه‌های دوم توانایی بالایی در تمایز رفتار دینامیکی سیگنال‌های خطاهای امپدانس بالا نسبت به تغییرات بار دارد. ویژگی‌های استخراج شده از مؤلفه‌های دوم نسبت به سایر مؤلفه‌ها دارای واریانس کم‌تر و تکرارپذیری بیش‌تری بودند. از سیگنال مؤلفه‌های دوم، شش ویژگی کلیدی (F1 تا F6) استخراج شده است. این ویژگی‌ها شامل معیارهای آماری و حوزه فرکانسی بودند که به‌طورخاص برای تمایز سیگنال‌های خطا و تغییرات بار طراحی شدند. به‌عنوان نمونه، F1 (میانگین انرژی) نشان‌دهنده سطح انرژی کلی سیگنال و تفاوت چشم‌گیر آن در دو کلاس بود. F2 (انحراف معیار) نشان‌دهنده نوسانات سیگنال و حساسیت به وقوع خطا است. F3 تا F6 ترکیبی از شاخص‌های فرکانسی و زمانی بودند که دقت شناسایی را بهبود بخشیدند. نتایج نشان داد که ویژگی‌های استخراج‌شده از مؤلفه‌های دوم، به‌ویژه در تمایز سیگنال‌های خطا از تغییرات بار، عملکرد بسیار مناسبی داشته و زمینه‌ساز مدل‌سازی موفق در مراحل بعدی بودند.

[Downloaded from jeps.dezful.iau.ir on 2026-11-14]
[DOI: 10.82362/jeps.2025.1.533]
Journal of Novel Researches on Smart Power Systems - Vol. 14 - No. 1- Spring 2025



شکل(۶): مؤلفه‌ها پس از اعمال روش پیشنهادی بر روی سیگنال خطاهای امپدانس بالا

Figure (6): IMFs after applying proposed method to the HIFs signal



شکل(۷): مؤلفه‌ها پس از اعمال روش پیشنهادی بر روی سیگنال تغییرات بار

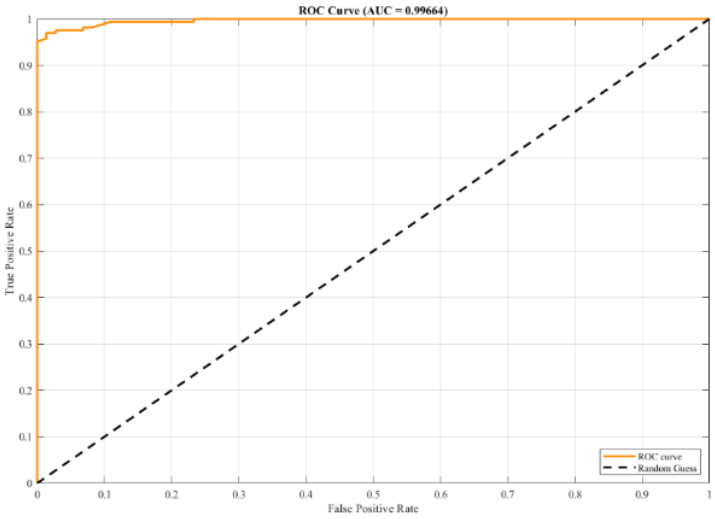
Figure (7): IMFs after applying proposed method to the load switching signal

[Downloaded from jeps.dezful.iau.ir on 2026-11-14]

Journal of Novel Researches on Smart Power Systems - Vol. 14 - No. 1- Spring 2025
[DOI: 10.82362/jeps.2025.1.533]

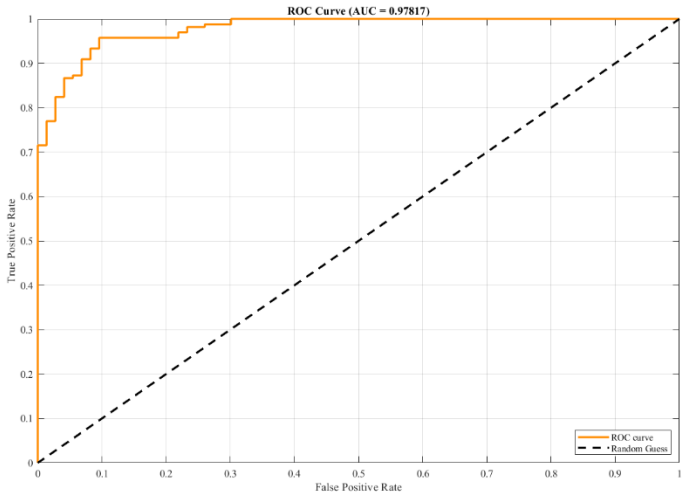
۴-۳- تصمیم‌گیری و طبقه‌بندی

در ابتدا کتاب‌خانه‌ها و ابزارهای موردنیاز را در زبان برنامه نویسی پایتون فراخوانی می‌کنیم. از آن‌جایی‌که بخش زیادی از پردازش با استفاده از Google colab صورت گرفته است پس رابطی بین Google Colab و Google drive درنظر گرفته شده است. مجموعه داده‌ها از یک فایل Excel در Google Drive فراخوانی شده است. داده‌ها به ویژگی‌ها و برچسب‌ها و هم‌چنین به مجموعه داده‌های آموزشی و تست تقسیم شده است. یک مقیاس‌بندی بر روی آن‌ها اعمال شده است. مدل RF ایجاد شده است. مدل‌ها با استفاده از داده‌های آموزش، آموزش داده شده است. پیش‌بینی برچسب‌ها با استفاده از داده‌های تست به‌دست می‌آید. در مراحل پایانی ارزیابی دقت مدل‌ها بیان شده است و معیار اعتبارسنجی که ماتریس درهم‌ریختگی می‌باشد نیز نمایش داده شده است. به‌منظور ارزیابی عملکرد روش پیشنهادی، مقایسه‌ای با روش تجزیه حالت تجربی تجمعی کامل با داده کمکی نویز انجام شده است. به‌عبارتی دیگر از این روش در قسمت استخراج ویژگی استفاده شده است و مجدد روش الگوریتم جنگل تصادفی اعمال شده است و نتایج، نشان دهنده بهبود روش پیشنهادی می‌باشد. شکل‌های (۸) و (۹) نمودار منحنی ROC و AUC به‌دست آمده برای هر کدام از روش‌های تجزیه حالت تجربی مجموعه کامل با نویز تطبیقی و تجزیه حالت تجربی تجمعی کامل با داده کمکی نویز نشان داده شده است.



شکل(۸): نمودار منحنی ROC و AUC به‌دست آمده از روش پیشنهادی

Figure (8): ROC and AUC curve obtained from the proposed method



شکل(۹): نمودار منحنی ROC و AUC به‌دست آمده از روش پیشنهادی

Figure (9): ROC and AUC curve diagram obtained from the proposed method

[Downloaded from jeps.dezful.iau.ir on 2026-11-14]

Journal of Novel Researches on Smart Power Systems - Vol. 14 - No. 1- Spring 2025
[DOI: 10.82362/jeps.2025.1.533]

همان‌طور که م شاهده می شود منحنی ROC روش پی شنهادی نتایج قابل قبولی ن سبت به روش تجزیه حالت تجربی تجمعی کامل با داده کمکی نویز از خود ن شان داده ا ست. هم‌چنین مقدار AUC همان‌طور که م شاهده می شود در روش پی شنهادی مقداری اثرگذارتر دارد.

ماتریس درهم‌ریختگی به‌دست آمده از طبقه‌بندی RF_ICEEMDAN و RF_CEEMDAN برای شبکه تست ۳۴ شینه IEEE در شکل (۱۰) نشان داده شده است. روابط معیارهای ارزیابی برای این ماتریس محاسبه شده است. هم‌چنین جدول (۲) نتایج به‌دست آمده از روابط معیارهای ارزیابی برای شبکه تست ۳۴ شینه IEEE با استفاده از روش‌های RF_ICEEMDAN و RF_CEEMDAN را نشان می‌دهد.



(ب) (الف)

شکل (۱۰): ماتریس درهم ریختگی با استفاده از روش RF_ICEEMDAN (الف) و RF_CEEMDAN (ب)

Figure (10): Confusion matrix using RF ICEEMDAN (a) and RF_CEEMDAN (b) methods

Table (2): Evaluation results of proposed method with another method

جدول(۲): نتایج ارزیابی روش پیشنهادی با روش دیگر

روش	دقت (٪)	حساسیت (٪)	اختصاصیت (٪)	دقت (٪)	ضریب تشابه (٪)	امتیاز F1-(٪)
RF_CEEMDAN	۹۱/۵۹۶	۹۴/۹۱	۹۰/۵۰۲	۷۶/۷۱	۸۴/۸۴۸	۸۴/۸۴۴
RF_ICEEMDAN	۹۷/۴۷	۹۴/۶۶	۹۸/۷۷۳	۹۷/۲۶	۹۵/۹۴۵	۹۵/۹۴۲

همان‌طور که مشخص است، نتایج قابل قبول و با کیفیتی را در مقایسه با روش RF_CEEMAN به‌دست آمده است.

۵- نتیجه‌گیری

روش ارائه شده در این پژوهش ترکیبی از تجزیه حالت تجربی مجموعه کامل با نویز تطبیقی و یادگیری ما شین می‌با شد. ابتدا مجموعه داده‌ها جمع آوری شده است. از تجزیه حالت تجربی با نویز تطبیقی به‌منظور استخراج ویژگی بر روی مجموعه نمونه‌برداری های انجام شده از داده‌ها اعمال شده است. ویژگی‌های استخراج شده برای طبقه‌بندی به‌عنوان ورودی به الگوریتم جنگل تصادفی وارد شده است.

این روش بر روی شبکه تست ۳۴ شینه IEEE پیاده سازی شده ا ست. همان‌طور که در نتایج قابل م شاهده ا ست، این روش توانست وقوع و یا عدم وقوع تشخیص خطای امپدانس بالا در شبکه تست را با دقت قابل قبول و بالایی بیان کند. دقت به‌دست آمده از روش پیشنهادی بر روی شبکه تست ۳۴ شینه IEEE، ۹۷/۴۷ درصد می‌باشد. باتوجه به نتایج به‌دست آمده، این روش حالت بهره‌برداری عادی شبکه قدرت را از حالتی که خطای امپدانس بالا رخ داده است، تفکیک کرده است.

[Downloaded from jeps.dezful.iau.ir on 2026-11-14]
Journal of Novel Researches on Smart Power Systems - Vol. 14 - No. 1- Spring 2025
[DOI: 10.82362/jeps.2025.1.533]

مراجع
References

[1] M. Karimi and N. Ghaffarzadeh, "High impedance fault detection based on current harmonic analysis using Chirp Z transform," Energy Systems, vol. 13, no. 3, pp. 813-833, 2022, (doi: 10.1007/s12667-021-00431-1).

[2] S. Wang and P. Dehghanian, "On the use of artificial intelligence for high impedance fault detection and electrical safety," IEEE Transactions on Industry Applications, vol. 56, no. 6, pp. 7208-7216, 2020, (doi: 10.1109/TIA.2020.3017698).

[3] M. S. Attar, "High-Impedance Fault Detection in Electric Power Distribution Networks: A Review," (in eng), Journal of Novel Researches on Smart Power Systems, Review article vol. 13, no. 3, pp. 53-73, 2024. [Online]. Available: http://jeps.dezful.iau.ir/article-1-520-fa.html

[4] A. Ranjbar and A. H. Rahmani, "Fault Diagnosis by Using the Multi-class Support Vector Machine," (in eng), Journal of Novel Researches on Smart Power Systems, Applicable vol. 8, no. 3, pp. 27-35, 2019] .Online]. Available: http://jeps.dezful.iau.ir/article-1-220-fa.html

[5] T. A. Brasil, J. N. Gois, and J. A. Neto, "Detection of High Impedance Faults in Primary Distribution Grid using Support Vector Machines Classification," in 2021 14th IEEE International Conference on Industry Applications (INDUSCON), 2021: IEEE, pp. 1138-1145, (doi: 10.1109/INDUSCON51756.2021.9529518).

[6] A. Ahmadi, E. Aghajari, and M. Zangeneh, "High-impedance fault detection in power distribution grid systems based on support vector machine approach," Electrical Engineering, vol. 104, no. 5, pp. 3659-3672, 2022, (doi: 10.1007/s00202-022-01544-1).

[7] B. K. Chaitanya, A. Yadav, and M. Pazoki, "An intelligent detection of high-impedance faults for distribution lines integrated with distributed generators," IEEE Systems Journal, vol. 14, no. 1, pp. 870-879, 2019, (doi: 10.1109/JSYST.2019.2911529).

[8] B. Chaitanya, A. Yadav, and M. Pazoki, "High impedance fault detection scheme for active distribution network using empirical wavelet transform and support vector machine," in 2020 15th International Conference on Protection and Automation of Power Systems (IPAPS), 2020: IEEE, pp. 149-152, (doi: 10.1109/IPAPS52181.2020.9375620).

[9] M. Sarwar, F. Mehmood, M. Abid, A. Q. Khan, S. T. Gul, and A. S. Khan, "High impedance fault detection and isolation in power distribution networks using support vector machines," Journal of King Saud University-Engineering Sciences, vol. 32, no. 8, pp. 524-535, 2020, (doi: 10.1016/j.jksues.2019.07.001).

[10] H. Bai, B. Tang, T. Cheng, and H. Liu, "High impedance fault detection method in distribution network based on improved Emanuel model and DenseNet," Energy Reports, vol. 8, pp. 982-987, 2022, (doi: 10.1016/j.egyr.2022.05.199).

[11] K. Shihabudheen *et al.*, "Detection of high impedance fault using machine learning techniques," in TENCON 2019-2019 IEEE Region 10 Conference (TENCON), 2019: IEEE, pp. 2117-2122, (doi: 10.1109/TENCON.2019.8929365).

[12] V. Veerasamy *et al.*, "LSTM recurrent neural network classifier for high impedance fault detection in solar PV integrated power system," IEEE access, vol. 9, pp. 326 ,۲۰۲۱ ,۳۲۶۸۷-۷۲(doi: 10.1109/ACCESS.2021.3060800).

[13] T. Biswal and S. Parida, "High impedance fault detection in Microgrid system using Discrete wavelet transform and Support vector machine," in 2022 Second International Conference on Power, Control and Computing Technologies (ICPC2T), 2022: IEEE, pp. 1-6, (doi: 10.1109/ICPC2T53885.2022.9777069).

[14] V. Veerasamy *et al.*, "High-impedance fault detection in medium-voltage distribution network using computational intelligence-based classifiers," Neural Computing and Applications, vol. 31, pp. 9127-9143, 2019, (doi: 10.1007/s00521-019-04445-w).

[DOI: 10.82362/jeps.2025.1.533] Journal of Novel Researches on Smart Power Systems - Vol. 14 - No. 1- Spring 2025 [Downloaded from jeps.dezful.iau.ir on 2026-11-14]

[15] M. Bhatnagar, A. Yadav, and A. Swetapadma, "Fuzzy based relaying scheme for high impedance faults in DG integrated distribution system," Electric Power Systems Research, vol. 202, p. 107602, 2022, (doi: 10.1016/j.epsr.2021.107602).
[16] S. Lavanya, S. Prabakaran, and N. A. Kumar, "A deep learning technique for detecting high impedance faults in medium voltage distribution networks," Engineering, Technology & Applied Science Research, vol. 12, no. 6, pp. 9477-9482, 2022, (doi: 10.48084/etasr.5288).
[17] M. Eissa, M. Awadalla, and A. Sharaf, "A new high impedance fault detection technique using deep learning neural network," in Artificial Intelligence Applications in Electrical Transmission and Distribution Systems Protection: CRC Press, 2021, pp. 179-195.
[18] K. Rai, F. Hojatpanah, F. B. Ajaei, J. M. Guerrero, and K. Grolinger, "Deep learning for high-impedance fault detection and classification: transformer-CNN," Neural Computing and Applications, vol. 34, no. 16, pp. 14067-14084, 2022, (doi: 10.1007/s00521-022-07219-z).
[19] H. Lala and S. Karmakar, "Detection and experimental validation of high impedance arc fault in distribution system using empirical mode decomposition," IEEE Systems Journal, vol. 14, no. 3, pp. 3494-3505, 2020, (doi: 10.1109/JSYST.2020.2969966).
[20] X. Wang *et al.*, "High impedance fault detection method based on improved complete ensemble empirical mode decomposition for DC distribution network," International Journal of Electrical Power & Energy Systems, vol. 107, pp. 538-556, 2019, (doi: 10.1016/j.ijepes.2018.12.021).
[21] Y. Liu, M. Razeghi-Jahromi, and J. Stoupis, "Unsupervised High Impedance Fault Detection in Distribution Networks With Autoencoder," IEEE Transactions on Industry Applications, 2025, (doi: 10.1109/TIA.2025.3544169).
[22] M. S. Attar and M .R. Miveh, "High- Impedance Fault Detection in Distribution Networks Based on Support Vector Machine and Wavelet Transform Approach (Case Study: Markazi Province of Iran)," Energy Science & Engineering, vol. 13, no. 3, pp. 1171-1183, 2025, (doi: https://doi.org/10.1002/ese3.2056).
[23] Z. Zhang, Y .Li, Z. Wang, J. Liu, A. Chen, and Y. Cao, "A data-driven impedance estimation and matching method for high impedance fault detection and location of distribution networks," International Journal of Electrical Power & Energy Systems, vol. 165, p. 110499 ,۲۰۲۵ ,(doi: 10.1016/j.ijepes.2025.110499).
[24] P. V. Dhawas, P. P. Bedekar, S. Dambhare, and P. V. Nandankar, "Advancement of High-Impedance Fault Detection in Primary Distribution Systems Using a Sequence Components Energy Detector," IEEE Transactions on Circuits and Systems I: Regular Papers, 2025, (doi: 10.1109/TCSI.2025.3544894).
[25] A. Vinayagam *et al.*, "Discrimination of high impedance fault in microgrid power network using semi-supervised machine learning algorithm," Ain Shams Engineering Journal, vol. 16, no. 1, p. 103187, 2025, (doi: 10.1016/j.asej.2024.103187).
[26] A. A. Janiabadi and S. Hasheminejad, "A new algorithm for the identification of high impedance faults in distribution systems utilizing S transform," Ain Shams Engineering Journal, vol. 16, no. 4, p. 103334, 2025, (doi: 10.1016/j.asej.2025.103334).
[27] H. Bai, J.-H. Gao, T. Liu, Z.-Y. Guo, and M.-F. Guo, "Explainable incremental learning for high-impedance fault detection in distribution networks," Computers and Electrical Engineering, vol. 122, p. 110006, 2025, (doi: 10.1016/j.compeleceng.2024.110006).
[28] A. Mohammadi, M. Jannati, and M. Shams, "Using deep transfer learning technique to protect electrical distribution systems against high-impedance faults," IEEE Systems Journal, vol. 17, no. 2, pp. 3160-3171, 2023, (doi: 10.1109/JSYST.2023.3234655).
[29] L. Breiman, "Random forests," Machine learning, vol. 45, pp. 5-32, 2001, (doi: 10.1023/A:1010933404324).
[30] L. Breiman, "Bagging predictors," Machine learning, vol. 24, pp. 123-140, 1996, (doi: 10.1007/BF00058655).
[31] T. Lai, L. Snider, E. Lo, C. Cheung, and K. Chan, "High impedance faults detection using artificial neural network," 2003.

[Downloaded from jeps.dezful.iau.ir on 2026-11-14]
[DOI: 10.82362/jeps.2025.1.533]
Journal of Novel Researches on Smart Power Systems - Vol. 14 - No. 1- Spring 2025

زیرنویس‌ها

1. High Impedance Fault (HIF)
2. Dense Convolutional Neural Network
3. Long Short-Term Memory (LSTM)
4. Complete Ensemble Empirical Mode Decomposition with Noise-Assisted Data (CEEMDAN)
5. Empirical Mode Decomposition (EMD)
6. Autoencoder
7. Multi Layer Perceptron (MLP)
8. Photovoltaics (PV)
9. Explainable Incremental Learning
10. Discrete Wavelet Transform (DWT)
11. Wigner-Ville Transform
12. Improved Complete Ensemble Empirical Mode Decomposition with Adaptive Noise (ICEEMDAN)
13. Random Forest (RF)
14. Intrinsic Mode Function (IMF)
15. Mean Amplitude
16. Energy
17. Standard Deviation
18. Peak-to-Peak
19. Skewness
20. Kurtosis
21. overfitting
22. Decision Tree
23. True Positive
24. True Negative
25. False Positive
26. False Negative
27. Sensitivity
28. Accuracy
29. Specificity
30. Precision
31. F-Score
32. Dice

[Downloaded from jeps.dezful.iau.ir on 2026-11-14]
Journal of Novel Researches on Smart Power Systems - Vol. 14 - No. 1- Spring 2025
[DOI: 10.82362/jeps.2025.1.533]